

이론정련 지식기반인공신경망을 이용한 귀납적 학습

심 동 회^{*}

요 약

귀납적학습 알고리즘과 분석적학습 알고리즘을 결합한 지식기반인공신경망이 제안된 후, 이를 개선한 TopGen, TR-KBANN, THRE-KBANN과 같은 영역이론정련알고리즘이 제시되었다. 그러나 이들은 모두 KBANN과 같이 영역이론이 있을 경우에만 사용할 수 있다. 본 연구에서는 영역이론이 없이 예제만 있는 경우 KBANN으로 표기하는 알고리즘을 제시하였다. KBANN으로 표현된 영역이론은 THRE-KBANN으로 정련화될 수 있다. 이 알고리즘을 귀납적 학습에서 사용하는 몇 개의 문제영역에 적용하여 실험한 결과 C4.5보다 좋은 성능을 나타냈다.

Inductive Learning using Theory-Refinement Knowledge-Based Artificial Neural Network

Shim Donghee^{*}

ABSTRACT

Since KBANN (knowledge-based artificial neural network) combining the inductive learning algorithm and the analytical learning algorithm was proposed, several methods such as TopGen, TR-KBANN, THRE-KBANN which modify KBANN have been proposed. But these methods can be applied when there is a domain theory. The algorithm representing the problem into KBANN based on only the instances without domain theory is proposed in this paper. Domain theory represented into KBANN can be refined by THRE-KBANN. The performance of this algorithm is more efficient than the C4.5 in the experiment for some problem domains of inductive learning.

1. 서 론

기계학습의 문제는 영역이론(Domain Theory)이 없는 경우와 있는 경우로 구분될 수 있다[1-4]. 영역이론이 없는 경우는 예제들을 이용하여 귀납적학습을 하게되므로 일반적으로 많은 예제를 필요로 하는 데이터한 귀납적 학습방법으로는 ID3계열의 학습방법이 유명하다[1,2]. 한편 영역이론이 있는 경우 이를 이용하여 학습을 하는데 이는 연역적 학습에 속하게 되며 설명근거학습이 이 유형에 해당한다. 그러나 영역이론이 불완전한(Incomplete) 경우에는 일반적으로 이 설명근거학습방법은 약점을 갖게된다[1,3]. 이와 같이 영역이론이 불완전한 경우에 대하여 제시된

방법인 KBANN은 명제논리로 표현되는 문제에 대해서는 그 성능이 입증된 바 있다[1,5,6]. 이 KBANN은 신경망을 이용하여 불완전한 영역이론을 표현하고, 이 신경망을 역전파알고리즘을 이용하여 예제를 이용하여 학습시킨다. 즉 불완전한 영역이론과 예제를 이용하여 학습을 하므로 연역적학습과 귀납적 학습을 혼합한(Hybrid) 방법에 해당한다[1,5,6].

이 KBANN에서는 영역이론을 신경망으로 표현한 후 신경망의 구조를 변경시키지 않고 예제를 이용하여 학습을 시킨다. 그런데 영역이론에 많은 오류가 있을 경우 이 영역이론을 올바르게 수정해 나가는 것을 영역이론정련(Domain Theory Refinement)이라고 한다[7-9]. 영역이론정련 측면에서 KBANN을 개선시킨 방법으로 TopGen, THRE-KBANN, TR-KBANN 등이 제시된바 있다[7,8,10,11]. KBANN을

^{*} 정희원, 전주대학교 정보기술컴퓨터공학부

포함한 이 방법들은 모두 연역적 학습과 귀납적 학습을 혼합한 방법이기 때문에 당연히 영역이론이 불완전한 경우에 대해서만 그 성능이 입증되었다. 그러나 이 방법을 영역이론이 없이 예제만 있는 경우에 적용할 수도 있을 것이다.

본 연구에서는 영역이론이 없이 예제만 있는 경우 이를 이용해 KBANN으로 영역이론을 표현하는 알고리즘을 제시하였다. 그리고 KBANN으로 표현된 내재된 불완전한 영역이론을 THRE-KBANN을 이용하여 정련하는 실험을 여러 문제영역에 대하여 실행하였다. 그리고 이 결과를 귀납적 학습에 해당하는 ID3 계열의 C4.5와 비교하였다. 그래서 2장에서는 이 논문에서 이용하는 KBANN과 THRE-KBANN에 대하여 개괄적인 설명을 하였으며, 3장에서는 예제를 KBANN으로 표현하는 알고리즘을 제시하였으며, 4장에서는 실험에 사용한 문제영역을 소개하고 실험결과를 제시하였다.

2. KBANN과 THRE-KBANN

2.1 KBANN

<그림 1>에 나타난 지식기반인공신경망(KBANN: Knowledge-based Artificial Neural Network)에서는 어떤 문제영역에 대한 이론이 명제논리를 이용한 혼절(Horn Clause) 형태의 규칙으로 표현되어 있으면 이를 신경망으로 변환한다[5,6]. 그리고 예제에 의거하고 역전과 알고리즘[12]을 이용하여 신경망을 학습시킨다. 그런데 KBANN에서는 규칙들을 신경망으로 변환한 후, 신경망 구조를 변화시킬 수 없다. 만약 KBANN에서 다루는 최초의 규칙집합이 완벽하지 않은 경우 규칙집합이 갖고 있는 오류의 수정을 위하여 신경망 구조는 변화될 수 있어야 한다[7,8]. 이 신경망 구조의 변경이 바로 영역이론정련화[9]에 해당한다. 그래서 이러한 KBANN의 단점인 영역이론정련화기능 부족을 보완할 수 있도록 KBANN을 확장 시키는 연구도 이루어졌다[7,8,10,11].

2.2 THRE-KBANN

THRE-KBANN(Theory-REfinement Knowledge-Based Artificial Neural Network)은 이론정련지식기반신경망으로 부르는데 KBANN에 영역이론정련기능을 부여한 방법에 해당한다.

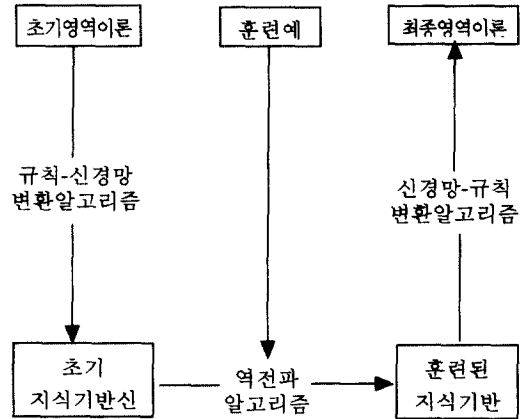


그림 1. 지식기반신경망에서의 처리절차

(1) 영역이론의 오류

영역이론정련방법에서는 먼저 양부제 및 음부제를 정의하는데 이는 신경망을 구성하는 각 노드 측면에서 다음과 같이 정의될 수 있다. 부제에 대하여 어떤 노드가 양인 경우 음으로 바꾸어 진제가 되면 양부제(false positive)라 하고, 노드가 음인 경우 양으로 바꾸어 진제가 되면 음부제(false negative)라고 한다. 그리고 지식기반인공신경망에서 활성화값(activation value)은 1에 가까우면 이는 양으로 간주하고 0에 가까우면 이를 음으로 간주한다.

한편 영역이론오류는 과잉구체화나 과일일반화에 의해서 발생한다. 먼저 과잉구체화란 범주에 해당하는 예제를 부로 분류하는 경우로서 음부제에 해당한다. 이는 규칙의 조건이 추가됨으로 인하여 결론에 대한 and 조건이 강화되었을 때 발생할 수 있고, 또 적당한 규칙이 누락되어 or 조건이 부족하게 되었을 때 발생할 수 있고 또는 조건의 not이 잘못 표기되었을 때 발생할 수 있다. 과일일반화란 과잉구체화의 반대로서 범주에 해당하지 않는 예제를 진으로 분류하는 경우로서 양부제에 해당한다. 이는 규칙의 조건이 누락됨으로 인하여 결론에 대한 and 조건이 완화되었을 때 발생할 수 있고, 또 잘못된 규칙이 추가되어 or 조건이 완화되었을 때 발생할 수 있고 또는 조건의 not이 잘못 표기되었을 때 발생할 수 있다.

(2) THRE-KBANN 알고리즘

THRE-KBANN (THEory REfinement for KBANN) 알고리즘[10]은 다음과 같이 작동한다.

- ① 훈련예제를 훈련집합, 조정집합1, 조정집합2, 시험집합으로 임의로 분류한다.
- ② 훈련집합을 이용하여 훈련된 KBANN을 생성한다.
- ③ 조정집합1을 이용하여 다음의 절차에 의하여 신경망을 생성한다.
 - ㉠ 각 노드의 음부제와 양부제의 값을 0으로 초기화한다.
 - ㉡ 조정집합1에서 각 부제에 대하여 각 노드에서의 양부제, 음부제 여부를 판단하여 해당 값을 증가시킨다.
 - ㉢ 양부제와 음부제의 합이 가장 큰 노드를 선정한다. 같은 경우는 양부제나 음부제의 비율이 편중된 노드, 입력계층에 가까운 노드 순으로 선정한다.
 - ㉣ 노드 추가방법에 의거하여 노드를 추가하여 신경망을 생성한다.
- ④ 새로운 신경망을 조정집합2를 이용하여 훈련시키고 오류율이 이전의 신경망보다 높으면 위의 3)단계로 되돌아간다.
- ⑤ 시험집합을 이용하여 새로운 신경망의 오류율이 중지조건을 만족하면 이를 출력하고 만족하지 않으면 3으로 간다.

(3) THRE-KBANN에서 새로운 노드의 처리 방법

앞에서 소개한 알고리즘의 구체적 구현에서는 다음과 같은 처리가 필요하다.

1) 노드의 추가방법

새로운 노드의 추가위치가 결정되면 노드는 <표 1>에 나타난 바와 같이추가된다. or 노드에서 음부

제를 해결하기 위하여 새로운 노드 N을 만들어 A에 or로 연결할 때 이 링크의 가중치만 W로 하면 된다. 양부제를 해결하기 위하여 생성된 노드 N1과 N2에 대해서는 A-N2 및 N1-N2 링크가중치 모두 W로 하며 N2의 bias는 $-3W/2$ 로 한다. 한편 and노드에서 음부제를 해결하기 위하여 생성된 노드 N1과 N2에 대해서는 A-N2 및 N1-N2 링크가중치 모두 W로 하며 N2의 bias는 $-W/2$ 로 한다. 양부제를 해결하기 위하여 새로운 노드 N을 만들어 A에 or로 연결할 때 이 링크의 가중치는 W로 하고 A의 bias는 $-5W/2$ 로 한다.

2) 새로운 노드의 bias

or노드에서 음부제 해결시와 and 노드에서 양부제 해결시노드 N의 bias 및 and 노드에서 음부제 해결시와 or 노드에서 양부제 해결시 노드 N1의 bias 모두 $-(2N-1)W/2$ (N는 하위계층 노드로부터의 링크 수)로 한다. 또한 or노드에서 음부제 해결시 A의 bias는 $-W/2$ 로, 양부제 해결시 N2의 bias는 $-3W/2$ 로, and 노드에서 음부제 해결시노드 N2의 bias는 $-W/2$ 로, 양부제 해결시 A의 bias는 $-5W/2$ 로 한다.

3) 새로운 노드로부터 상위계층 노드로의 링크 가중치

새로운 노드로부터 상위계층 노드로의 링크 가중치는 본래의 노드가 갖고 있던 가중치를 따르도록 한다.

3. THRE-KBANN의 적용방법

영역이론이 없이 훈련예제만 있는 경우에 THRE-KBANN을 적용하는 방법은 영역이론 대신 예제를 이용하여 KBANN으로 표현하는 방법만 제시하면

표 1. 노드 추가시 링크가중치와 bias

(W: 지식기반인공신경망에서 링크의 기본가중치)

현재 노드	음부제 해결시	양부제 해결시
or 노드 $A = B \vee C$ A의 bias= $-W/2$	$A = B \vee C \vee N$ A의 bias= $-W/2$ N-A 링크가중치=W	$A = B \vee C, N2 = A \wedge N1$ A의 bias= $-W/2$ A-N2 링크가중치=W N1-N2 링크가중치=W N2의 bias= $-3W/2$
and 노드 $A = B \wedge C$ A의 bias= $-3W/2$	$A = B \wedge C, N2 = A \vee N1$ A의 bias= $-3W/2$ A-N2 링크가중치=W N1-N2 링크가중치=W N2의 bias= $-W/2$	$A = B \wedge C \wedge N$ A의 bias= $-5W/2$ N-A 링크가중치=W

된다. 왜냐하면 이후의 단계는 THRE-KBANN 알고리즘을 적용하면 되기 때문이다.

3.1 훈련예제를 이용한 초기의KBANN 생성

다음과 같은 절차를 이용하여 신경망을 생성한다.

- 1) 출력노드를 생성하는데 출력노드수는 분류하는 클래스 수가 x 이면 $\ln(x)/\ln 2$ 보다 큰 최소의 정수로 한다.
- 2) 입력노드를 생성하는데 입력노드수는 입력을 구성하는 속성수에 의해 결정된다. 또한 속성마다 속성이 갖는 값의 수에 따라 노드수를 결정한다.
- 3) 중간계층노드를 생성한다. 이 노드수는 1개로 한다.
- 4) 각 노드간의 가중치는 임의의 작은 수로 한다.

3.2 초기 KBANN의 갱신

다음과 같은 알고리즘에 따라 KBANN의 중간노드수를 확장한다. 여기서는 중간노드를 하나씩 증가해서 KBANN을 생성하여 이중 오류율이 가장 적은 것을 선택한다. 이 알고리즘은 K개의 자료를 유지하는 측면에서 beam 탐색과 유사하다.

- 1) 훈련예제를 훈련집합, 조정집합, 시험집합으로 같은 수로 임의로 분류한다.
- 2) 훈련집합을 이용하여 KBANN을 훈련시키고 시험집합을 이용하여 오류율을 평가한다.
- 3) 다음과정을 반복한다.
 - a) 은닉노드수가 입력노드 수보다 크면단계4로 간다.
 - b) 은닉노드를 1개 추가하고 조정집합을 이용하여 이를 훈련시킨다.
 - c) 시험집합을 이용하여 오류율을 계산한다. 이 KBANN을 저장한다.
 - d) a단계로 간다.
- 4) 저장된 KBANN 중 오류율이 가장 적은 KBANN을 출력한다.

위에서 은닉노드의 수는 입력노드 수로 제한을 하였는데 이는 은닉노드가 많다고 무조건 효율적인 것은 아니기 때문에 휴리스틱하게 제한을 하였다.

3.3 THRE-KBANN의 적용

이제 KBANN이 생성되었으므로 THRE-KBA

NN 알고리즘을적용하면 된다.

4. 실험결과

3장에서 설명한 알고리즘을 기계학습의 귀납적 학습에서 사용되는 다음 6가지 자료에 적용하여 실험을 하였다.

4.1 조개 (Abalone) 자료

조개 나이는 조개셀을 잘라서 거기에 나타난 링의 수를 현미경으로 관찰하여 파악한 후링의 수에 1.5를 더하면 된다[13]. 그러나 이와 같은 작업에는 너무 많은 시간이 소요된다. 그래서 <표 2>에 나타난 자료를 이용하여 예측하는 것이 더 편리하다. 위와 같은 속성을 갖는 조개자료는 모두 4177개가 있으며 1살부터 29살까지에 걸쳐있다. 연속형 자료는 신경망에서의 처리를 위해 200단위로 나누어 처리했다.

4.2 자동차 자료

구입가격, 유지비, 문의 수, 탑승인원, lug_boot, 안전성과 같이 6개의 속성으로 구성된 자동차자료[13]가 1728개 있다. 누락된 속성값을 갖는 자료는 없다. 여기서 구분하는 클래스는 매우 안락, 안락, 보통, 불편의 4가지이다.

4.3 사목 자료

6×7 보드에서 두사람이 사목을 하는 경우의 자료[13]로서 42개의 보드가 각각의 속성으로 설정되어 있으며 각 속성은 말이 놓은 것에 따라 3개중의 값을 갖는다. 모두 67557개의 자료가 있다. 누락된 속성값을 갖는 자료는 없다. 여기서 구분하는 클래스는 승리, 패배, 비김의 3가지이다.

4.4 피임자료

이 자료는 인도네시아에서 수집된 피임자료이다 [13]. 부인의 연령, 부인의 교육수준, 남편의 교육수준, 출생자녀수, 부인의 종교, 부인의 직업유무, 남편의 직종, 생활수준, 뉴스매체 접근정도와 같은 속성으로 구성된 1473개의 자료다. 여기서 구분하는 클래스는 피임을 안하는 경우, 단기피임, 장기피임과 같이 3가지이다. 속성값이 누락된 자료는 없다.

4.5 성인자료

이 자료는 1994년 미국의 인구센서스자료에서 성

표 2. 소개자료의 속성

속성명	유형	설명	단위
성	nomial	수컷, 암컷, 어린것	
길이	연속형	가장 긴 뿔	mm
직경	연속형	길이에 수직	mm
높이	연속형	뿔안의 고기	mm
전체 질량	연속형	전체 무게	g
shucked 질량	연속형	고기 무게	g
viscera weight	연속형	피를 제거한 후의 무게	g
shell weight	연속형	말린 후의 무게	g
링	정수	1.5를 더하면 나이가 됨	

인에 대해 추출된 것으로 14가지의 속성을 가지고 있으며 년간소득이 5만불 이상인 지 미만인 지를 판단하는 것이다[15]. 성인자료는 모두 48842개가 있으며 이중 7%는 속성에 값이 없는 것을 포함하고 있다.

4.6 신용평가 자료

이 자료는 신용의 유무를 결정하는 자료로서 모두 16개의 속성을 갖고 있으며 모두 690개의 자료[14]가 있다. 이중 5% 정도인 37개의 자료는 속성값을 갖지 않는 속성을 포함하고 있다. 여기서 구분하는 클래스는 신용의 유무다.

4.7 실험결과

THRE-KBANN과 비교하기 위한 대상으로 귀납적 학습에서 많이 사용되는 C4.5 [16] release 8을 이용하였다. <표 3>은 실험결과를 나타내고 있는데 전체적으로 C4.5보다 다소 작은 오류율을 보이고 있다. <표 3>에는 예제를 이용하여 KBANN으로 표현된 영역이론의 중간노드수를 같이 나타냈다. 영역이론 정련전의 KBANN에서는 대체적으로 2-3개의 은닉

노드를 가질 때 낮은 오류율을 보였다. 또한 이 실험 결과 THRE-KBANN은 C4.5 낮은 오류율을 보여주고 있다. 이 실험은 30회 걸쳐서 이루어졌으며 THRE-KBANN의 오류율이 C4.5의 오류율보다 적다는 가설이 10% 수준에서 유의하게 나타났으며, 속성값 누락이 있는 경우에 해당하는 성인자료와 신용평가자료의 경우는 5%의 수준에서 유의하게 나타났다. 이 같은 유의수준의 차이는 속성값의 누락이 있는 경우는 영역이론정련의 효과가 나타난 것으로 해석할 수 있겠다.

5. 결론 및 향후과제

KBANN은 명제논리로 표현된 문제영역에 대하여 기존의 학습방법보다 더 효율적인 방법으로 입증된 바 있지만 실세계 대부분의 초기지식은 근사적으로 옳바르기 때문에 영역이론정련화가 필요하다. KBANN에 영역이론정련 능력을 부여한 것으로 TopGen, THRE-KBANN 등이 있는데 이들 모두 초기영역이론이 있어야 작업이 가능하다. 본 연구에서는 영역이론이 없이 예제만 있는 경우 이를 신경망으로 표현하고, 다시 예제를 이용하여 오류율을 최소화할 수 있도록 은닉계층을 단계적으로 삽입시켜 신경망의 구조를 변형하는 방법을 제시하였다. 신경망의 구조와 연결가중치는 문제에 대한 영역이론에 해당하며, 신경망의 구조가 변형되는 것은 영역이론의 정련으로 간주할 수 있다. 본 논문에서 제시한 THRE-KBANN을 이용하여 영역이론을 정련함으로써 일반 귀납적 학습의 대표적인 C4.5보다 우수할 수 있는 가능성을 제시하였다.

향후 연구로는 THRE-KBANN의 표현시에 아직은 명제논리에만 국한되고 있기 때문에 서술논리에

표 3. 실험결과 오류율

알고리즘	클래스수	C4.5	THRE-KBANN	초기KBANN에서 중간노드수	THRE-KBANN에서 추가된 노드수
소개자료	29	21.5	20.42	3	1
자동차자료	4	30.00	28.20	3	1
사육자료	3	34.20	32.66	2	2
피임자료	3	57.30	45.80	3	2
성인자료	2	15.54	10.88	2	2
신용평가자료	2	44.50	31.10	2	2

대해서는 적용할 수가 없는데 이에 대한 확장이 요망된다. 또한 영역이론정련시에 발생할 수 있는 극소점에서의 수렴하는 현상에 대한 연구도 필요하며, 정련된 영역이론을 규칙으로 표현방법에 대해서도 더욱 연구가 필요하다.

참 고 문 헌

- [1] Edited by J. W. Shavlik and T. G. Dietterich, General Aspects of Machine Learning, Readings in Machine Learning, Morgan Kaufmann, 1990
- [2] 박영택, 이강로, "ID3 계열의 귀납적 기계학습", 정보과학회지, 제13권 제5호, pp. 5-19, 5월, 1995년
- [3] 류광렬, "설명기반학습(EBL)의 원리와 응용", 정보과학회지, 제13권 제5호, pp. 20-32, 5월, 1995년
- [4] 이수원, "분석적 학습", 정보과학회지, 제13권 제5호, pp. 33-44, 5월, 1995년
- [5] G.G. Towell, "Symbolic Knowledge and Neural Networks: Insertion, Refinement, and Extraction", PhD thesis, University of Wisconsin-Madison, 1991
- [6] G. G. Towell, and J. W. Shavlik, "Using Symbolic Learning to Improve Knowledge-Based Neural Networks", Proceedings of AAAI, pp.177-182, 1992
- [7] D.W. Opitz, and J. W. Shavlik, "Heuristically Expanding Knowledge-Based Neural Networks", In Proceedings of the Thirteenth International Joint Conference on Artificial Intelligence, 1993, pp. 1360-1365, 1993
- [8] D. W. Opitz, 'An Anytime Approach to Connectionist Theory Refinement: Refining the Topologies of Knowledge-Based Neural Networks', PhD thesis, University of Wisconsin-Madison, 1995
- [9] D. Ourston and R. Mooney, "Theory Refinement Combining Analytical and Empirical Methods", Artificial Intelligence, Vol.66, pp. 273-309, 1994
- [10] 심동희, "지식기반인공신경망에서 은닉노드삽입을 이용한 영역이론정련화", 정보처리학회논문지 제3권 제7호, pp. 1773-1780, 12월, 1996년
- [11] 심동희, "지식기반인공신경망에서 관련있는 입력노드만 연계된 은닉노드를 이용한 영역이론정련화", 정보처리학회논문지 제4권 제11호, pp. 2780 - 2785, 11월, 1997년
- [12] D.E. Rumelhart, G.E.Hinton, and J. R. Williams, "Learning Internal Representations by Error Propagation", Vol. 1, pp. 318-363, MIT press, 1986
- [13] David Clark, Zoltan Schreter and Anthony Adams, "A Quantitative Comparison of Dystal and Backpropagation", Australian Conference on Neural Networks, 1996
- [14] <ftp://ftp.ics.uci.edu/pub/machine-learning-database/>
- [15] Ron Kohavi, "Scaling Up the Accuracy of Naive-Bayes Classifiers: a Decision-Tree Hybrid", Proceeding of the Second International Conference on Knowledge Discovery and Data Mining, 1996
- [16] J.R. Quinlan, "Improved Use of Continuous Attributes in C4.5", JAIR, Vol, 4, PP. 77-90, March, 1996



심 동 희

1980년 2월 서울대학교 공과대학
산업공학과 졸업
1982년 2월 서울대학교 대학원 산
업공학과 졸업(공학석사)
1994년 2월 고려대학교 대학원 전
산과학과 졸업(이학박사)
1982년 11월~1985년 3월 국토개

발연구원

1985년 3월~1990년 8월 해양수산개발연구원 책임연구원
1990년 9월~현재 전주대학교 정보기술컴퓨터공학부
부교수

관심분야: 기계학습, 네트워크보안, 온라인게임